Gestor de Processos
Núcleo Unix, Linux, Windows

Sistemas Operativos

2011 / 2012

Unix e Linux

Gestor de Processos

Contexto dos Processos

- Em Unix encontrava-se divido em duas estruturas:
  - A estrutura `proc` – sempre mantida em memória para suportar o escalonamento e o funcionamento dos signals
  - A estrutura `u` - `user` – só era necessária quando o processo se estivesse a executar → transferida para disco se houvesse falta de memória
- As estruturas `proc` eram organizadas num vector cuja dimensão ditava o número máximo de processos que o sistema poderia ter.

Unix - Contexto Núcleo de um Processo

- estrutura `proc`:
  - p_stat – estado do processo
  - p_pri – prioridade
  - p_sig – sinais enviados ao processo
  - p_time – tempo que está em memória
  - p_cpu – tempo de utilização
  - p_pid – identificador do processo
  - p_ppid – identificador do processo pai
- parte do contexto do processo necessária para efectuar as operações de escalonamento

- estrutura `u`:
  - registos do processador
  - pilha do núcleo
  - códigos de protecção (UID, GID)
  - referência ao directório corrente e por omissão
  - tabela de ficheiros abertos
  - apontador para a estrutura proc
  - parâmetros da função sistema em execução

Linux: task_struct

```
struct task_struct {
volatile long state;
unsigned long flags;
int sigpending;
mm_segment_t addr_limit;
struct exec_domain *exec_domain;
volatile long need_resched;
unsigned long ptrace;
int lock_depth;
unsigned int cpu;
int prio, static_prio;
struct list_head run_list;
prio_array_t *array;
unsigned long sleep_avg;
unsigned long last_run;
unsigned long policy;
unsigned long cpus_allowed;
unsigned int time_slice, first_time_slice;
atomic_t usage;
struct list_head tasks;
struct list_head ptrace_children;
struct list_head ptrace_list;
struct mm_struct *mm, *active_mm;
struct linux_binfmt *binfmt;
int exit_code, exit_signal;
int pdeath_signal;
unsigned long personality;
int did_exec:1;
unsigned task_dumpable:1;
pid_t pid;
pid_t pgrp;
pid_t tty_old_pgrp;
pid_t session;
pid_t tgid;
int leader;
struct task_struct *real_parent;
struct task_struct *parent;
struct list_head children;
struct list_head sibling;
struct task_struct *group_leader;
struct pid_link pids[PIDTYPE_MAX];
wait_queue_head_t wait_chldexit;
struct completion *vfork_done;
int *set_child_tid;
int *clear_child_tid;
unsigned long rt_priority;
unsigned long it_real_value, it_prof_value, it_virt_value;
unsigned long it_real_incr, it_prof_incr, it_virt_incr;
struct timer_list real_timer;
struct tms times;
struct tms group_times;
unsigned long start_time;
long per_cpu_utime[NR_CPUS], per_cpu_stime[NR_CPUS];
unsigned long min_flt, maj_flt, nswap, cmin_flt, cmaj_flt,cnswap;
int swappable:1;
uid_t uid,euid,suid,fsuid;
gid_t gid,egid,sgid,fsgid;
int ngroups;
gid_t groups[NGROUPS];
kernel_cap_t cap_effective, cap_inheritable, cap_permitted;
int keep_capabilities:1;
struct user_struct *user;
struct rlimit rlim[RLIM_NLIMITS];
unsigned short used_math;
char comm[16];
int link_count, total_link_count;
struct tty_struct *tty;
unsigned int locks;
struct sem_undo *semundo;
struct sem_queue *semsleeping;
struct thread_struct thread;
struct fs_struct *fs;
struct files_struct *files;
struct namespace *namespace;
struct signal_struct *signal;
struct sighand_struct *sighand;
sigset_t blocked, real_blocked;
struct sigpending pending;
unsigned long sas_ss_sp;
size_t sas_ss_size;
int (*notifier)(void *priv);
void *notifier_data;
sigset_t *notifier_mask;
void *tux_info;
void (*tux_exit)(void);
u32 parent_exec_id;
u32 self_exec_id;
spinlock_t alloc_lock;
spinlock_t switch_lock;
void *journal_info;
unsigned long ptrace_message;
siginfo_t *last_siginfo;
};
```

Porque motivo deixou de estar separada em duas estruturas?

Modo Utilizador/Modo Núcleo

- Processo em modo utilizador:
  - executa o programa que está no seu segmento de código
- Muda para modo sistema:
  - sempre que uma excepção ou interrupção é desencadeada
  - excepção ou interrupção que pode ser provocada pelo utilizador ou pelo hardware
- A mudança de modo corresponde a:
  - mudança para o modo de protecção mais privilegiado do processador
  - mudança do espaço de endereçamento do processo utilizador para o espaço de endereçamento do núcleo
  - mudança da pilha utilizador para a pilha núcleo do processo
- A pilha núcleo:
  - É usada a partir do instante em que o processo muda de modo utilizador para modo núcleo
  - está vazia quando o processo se executa em modo utilizador

Porque são necessárias duas pilhas?

Pilha Utilizador/Pilha Núcleo

- Porque são necessárias duas pilhas?
  - A pilha em modo utilizador é a base da computação dos programas
  - A pilha em modo núcleo tem de ser diferente para garantir a estanquicidade de informação entre a actividade das funções do núcleo e do utilizador
  - A pilha em modo núcleo está vazia quando o processo passa para modo utilizador e contem o contexto de invocação das funções do núcleo quando está em modo núcleo.
    - Como o processo se pode bloquear no núcleo tem de ser uma por processo para permitir guardar de forma independente o contexto
  - As interrupções do hardware também tem de ser servidas numa pilha
    - é um decisão de desenho ter uma pilha separada ou utilizar como "hospedeiro" a pilha núcleo do processo corrente.

Utilização da Pilha Núcleo

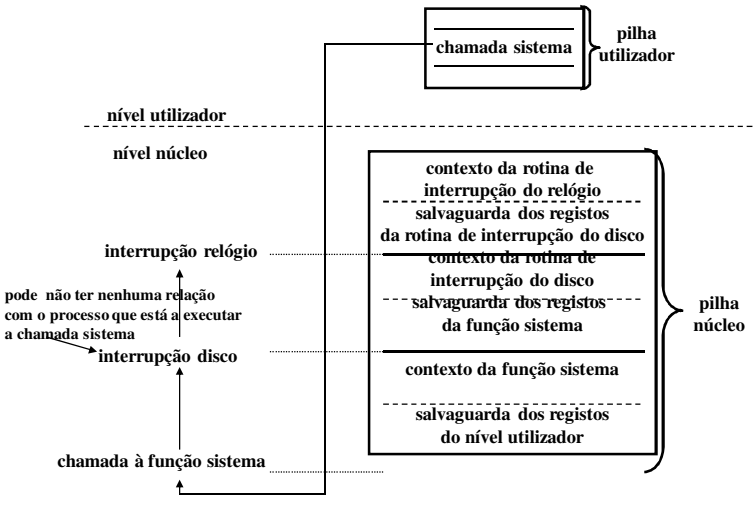

Escalonamento

- Prioridades em modo utilizador
  - O escalonamento é preemptivo
  - As prioridades em modo utilizador são calculadas dinamicamente em função do tempo de processador utilizado.
  - Quando o processo se bloqueia no núcleo é lhe atribuída uma prioridade em modo núcleo

- Prioridades em modo núcleo
  - O processo em modo núcleo não é comutado
  - As prioridades em modo núcleo são definidas com base no acontecimento que o processo está a tratar e são fixas
  - As prioridades núcleo são sempre superiores às prioridades utilizador.
  - Quando passa de modo núcleo para modo utilizador o sistema recalcula a prioridade do processo e atribui-lhe uma prioridade em modo utilizador

Unix: Prioridades

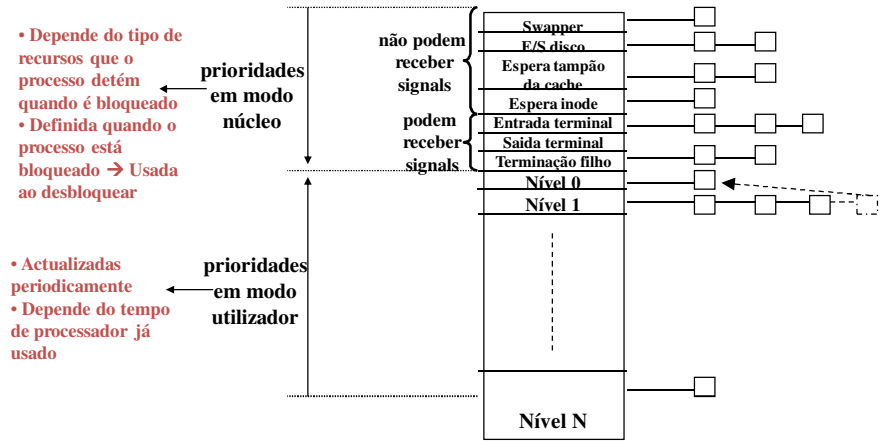

Unix: Prioridades em Modo Utilizador

- **Corre processo mais prioritario durante quantum (100 ms)**
- **Round-robin entre os mais prioritários**
- **Ao fim de 1 segundo (50 "ticks" de 20 ms) , recalcula prioridades:**
- **Para cada processo:**
  - **TempoProcessador = TempoProcessador / 2**
  - **Prioridade = TenpoProcessador / 2 + PrioridadeBase**
- **Em cada tick, rotina de tratamento da interrupção incrementa p_cpu**

Tempo (s)	Processo A		Processo B		Processo C	
	Prior.	T. Cpu	Prior.	T. Cpu	Prior.	T. Cpu
0	50	0	50	0	50	0
		50		-		-
1	62	25	50	0	50	0
		-		50	-	
2	56	12	62	25	50	0
		-		-		50
3	53	6	56	12	62	25
		56		-		-
4	64	28	53	6	56	12

Linux: Escalonamento

- Problema com algoritmo de escalonamento do Unix?
  - má escalabilidade com o número de processos a correr no sistema.
  - todos os segundos é necessário efectuar o cálculo das prioridades de todos os processos,
  - e este cálculo poder demorar algum tempo se for grande o número de processos em execução na máquina.
- Linux: Tempo dividido em épocas
  - Época termina quando todos os processos executáveis usaram o seu quantum (caso o pretendam)
- Processos diferentes têm durações do quantum diferentes
  - quantum = quantum_base + quantum_por_utilizar_epoca_anterior / 2
  - Pode ser reduzido com chamadas sistema

Linux: Prioridades

- Prioridade de um processo:
  - Linux: prioridade mais alta → mais prioritario
  - Prio = prio_base + quantum_por_usar_nesta_época - nice
- Processo mais prioritário é escolhido em primeiro lugar
- Melhora a escalabilidade. Porquê?
  - as durações de cada quantum são recalculadas uma vez por época, e
  - a duração da época aumenta à medida que aumenta o número de processos em execução simultânea
  - Versões iniciais ainda tinham problemas de escalabilidade, porque mantinham processos em lista única
  - Versão actual usa duas runQueues, cada uma uma multi-lista

Completely Fair Schedule

- CFS introduzido na versão 2.6.26 do Linux
- Objectivo:
  - reduzir os problemas das heurísticas de subida de prioridade na multilista.
- Voltamos à lista única mas agora é uma Red-Black tree:
  - Ordenação consoante o tempo de cpu utilizado
- A prioridade reflecte-se por um custo de cpu mais ou menos elevado, i.e.:
  - em processos com metade da prioridade de outros (cada microsegundo de cpu conta a dobrar)

Linux: Escalonamento “Real-Time”

- Também é possível definir prioridades estáticas superiores às dinâmicas (modo utilizador) – classe “real-time”
- Necessárias permissões
- Não é um sistema de tempo-real
- A partir do 2.6.26 existe um escalonador virtual que faz escalonamento de escalonadores:
  - o primeiro dos quais é um escalonador de “Tempo Real”.

Escalonamento: Chamadas Sistema

- nice (int val)
  - Decrementa a prioridade “val” unidades
  - Apenas superutilizador pode invocar com “val” negativo
- int getpriority (int which, int id)
  - Retorna prioridade do processo (ou grupo de procs.)
- setpriority (int which, int id, int prio)
  - Altera prioridade do processo (ou grupo de procs.)

Criação de um Processo

- Reservar uma entrada na tabela `proc` (Unix) e verificar se o utilizador não excedeu o número máximo de subprocessos
- Atribuir um valor ao `pid`, normalmente um mero incremento de um inteiro mantido pelo núcleo
- Copiar a imagem do processo pai:
  - Dado que a região de texto é partilhada, apenas é incrementado o contador do número de utilizadores que acedem a essa região
  - As restantes regiões são copiadas (algumas incrementalmente)
  - retornar o valor do `pid` do novo processo para o processo pai, zero para o processo filho (coloca os valores apropriados nas respectivas pilhas)

Criação de um Processo (cont.)

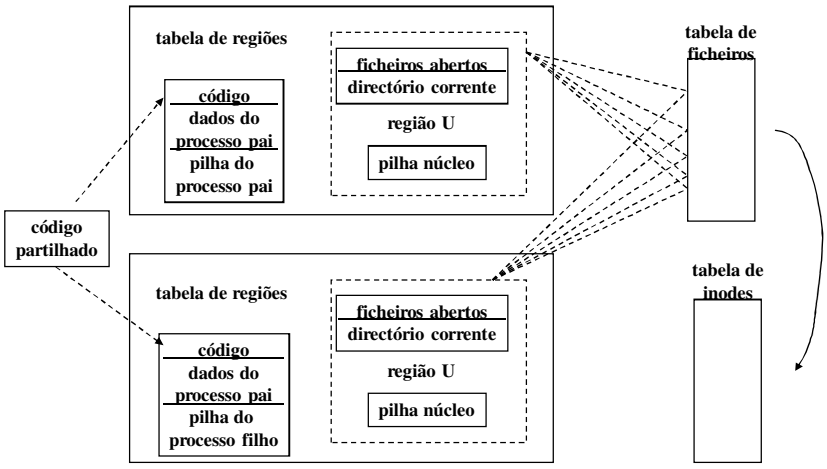

Terminação de um Processo

- Função exit:
  - fechar todos os ficheiros
  - libertar directório corrente
  - libertar regiões de memória
  - actualizar ficheiro com registo da utilização do processador, memória e I/O
  - enviar signal death of child ao processo pai (por omissão é ignorado)
  - registo proc / task mantém-se no estado zombie:
    - permite ao processo pai encontrar informação sobre o filho quando executa wait
- Função wait:
  - procura filho zombie
  - pid do filho e estado do exit são retornados através do wait
  - liberta a estrutura proc do filho
  - se não há filho zombie, pai fica bloqueado

Execução de um Programa

- A função exec executa um novo programa no âmbito de um processo já existente:
  - Verifica se o ficheiro existe e é executável
  - Copia argumentos da chamada a exec da pilha do utilizador para o núcleo (pois o contexto utilizador irá ser destruído)
  - Liberta as regiões de dados e pilha ocupadas pelo processo e eventualmente a região de texto (se mais nenhum processo a estiver a usar)
  - Reserva novas regiões de memória
  - Carrega o ficheiro de código executável
  - Copia os argumentos da pilha núcleo para a pilha utilizador
- O processo fica no estado executável
- O contexto núcleo mantém-se inalterado:
  - identificação
  - ficheiros abertos

Sincronização no Núcleo

- Vimos mecanismos que permitem às actividades a nível utilizador partilhar recursos de forma totalmente consistente
- Problema é genérico:
  - também se aplica a qualquer situação em que duas actividades concorrentes dentro do núcleo partilham recursos (aplica-se à maioria das tabelas e variáveis internas)
- Coloca-se quando:
  - Multiprocessadores
  - Uniprocessadores - interrupções

Sincronização no Núcleo Linux

- os programadores do núcleo do SO têm ao seu dispor um conjunto de funções de sincronização para programar as secções críticas.
  - São variantes das Fechar_hard e Abrir_hard vistas anteriormente
  - mecanismo do tipo *spinlock* (ciclo de espera activa até que o trinco abra), e desactivam as interrupções

Porquê ambas ?

Multiprocessadores !

Sincronização Interna: Wait Queues

- Objecto de sincronização do núcleo (e.g.: usado para bloquear processo num semáforo ou à espera do disco)
- Duas primitivas: sleep_on e wake_up
- sleep_on: bloqueia sempre o processo
- wake_up: desbloqueia todos os processos
  - Alguns podem ter de voltar a bloquear-se

Wait Queues: API Linux

- `init_waitqueue_head (&my_queue);`
- `sleep_on (&my_queue);`
- `wake_up (&my_queue);`
- `interruptible_sleep_on (&my_queue);`
- `wake_up_interruptible (&my_queue);`
- Estas funções são internas ao núcleo e não podem ser chamadas por código utilizador.

Signals

- Envio de um signal:
  - O sistema operativo coloca a 1 o bit correspondente ao signal, este bit encontra-se no contexto do processo a quem o signal se destina.
  - Não é guardado o número de vezes que um signal é enviado
- Tratamento do signal
  - Unix verifica se há signals:
    - quando o processo passa de modo núcleo para modo utilizador
    - entra ou sai do estado bloqueado
  - Linux verifica quando processo comuta para estado EmExecução.
  - No descritor do processo encontra-se o endereço da rotina de tratamento de cada signal
  - A pilha de modo utilizador é alterada para executar a função de tratamento do signal.
  - A função de tratamento executa-se no contexto do processo que recebe o signal como se fosse uma rotina normal

Tratamento de Signals

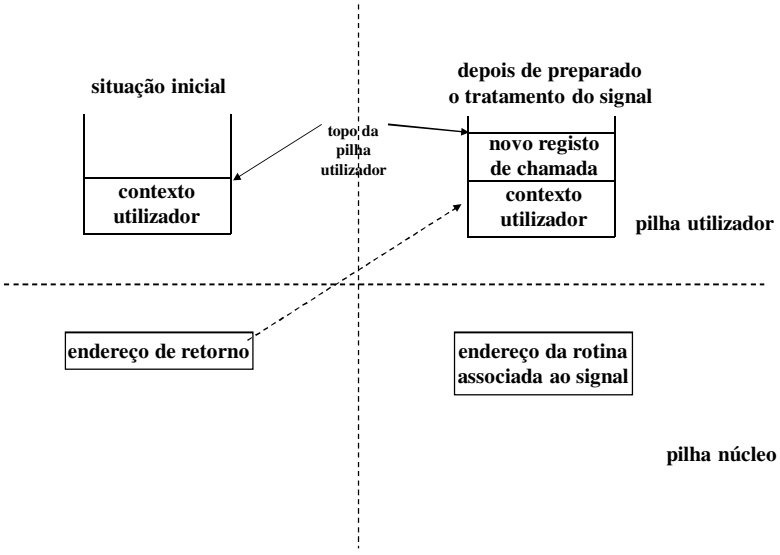

Gestor de Processos do Windows 2000

Objectos e Referências

- O sistema está estruturado internamente com base em objectos (e.g., processos, tarefas, ficheiros, trincos).
- Permitem:
  - Interface uniforme para acesso e partilha dos recursos do SO
  - Centralização das funções de segurança, autorização
  - Sistema simples de recolha automática dos objectos não necessários:
    - Gerir as referências para saber quando um objecto pode ser libertado porque ninguém o usa. (GC)

Objecto Processo

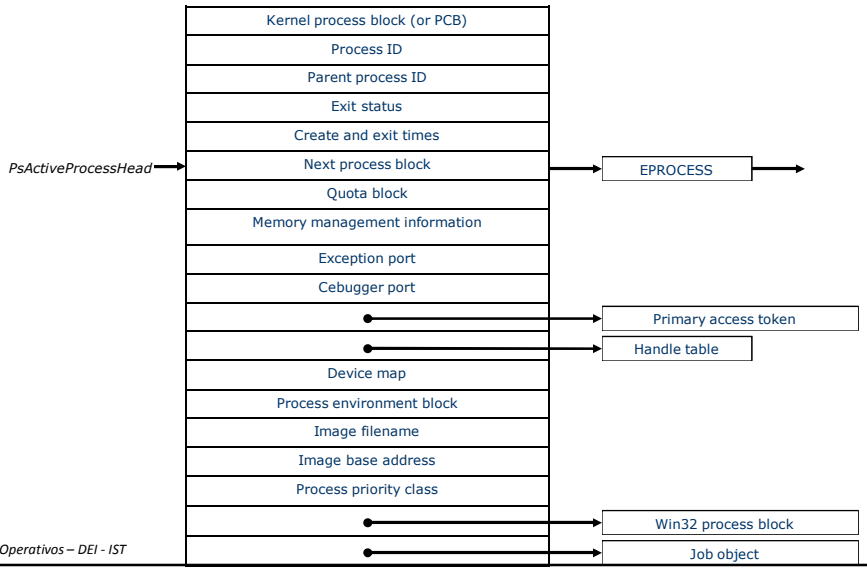

Objecto Thread

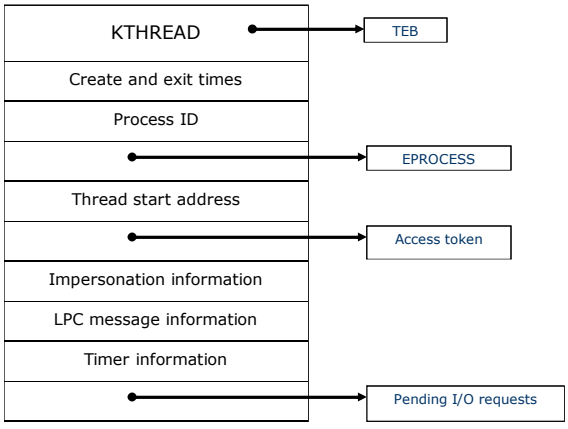

Prioridades

Dividem-se em dois grupos distintos

- Prioridades fixas para processos soft real time
- Prioridades variáveis para os processos interactivos

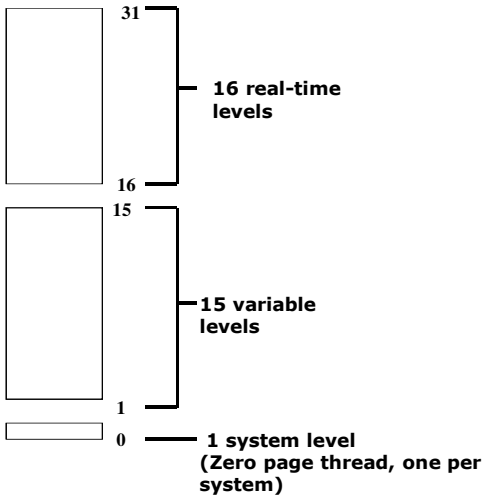

Diagrama de Estado das Tarefas em Windows

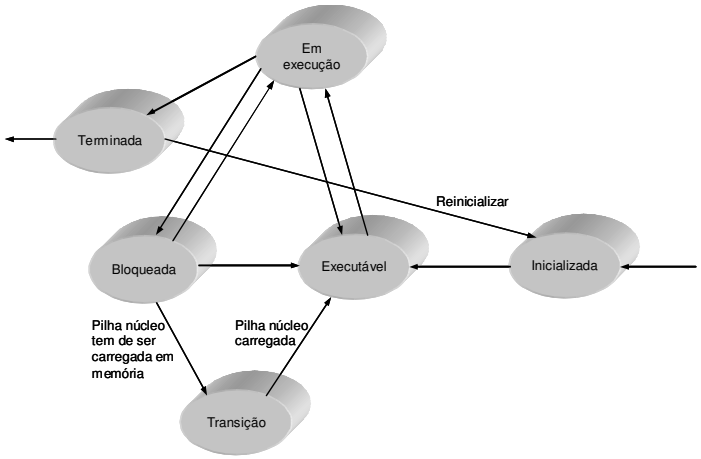

Mapeamento de Prioridades

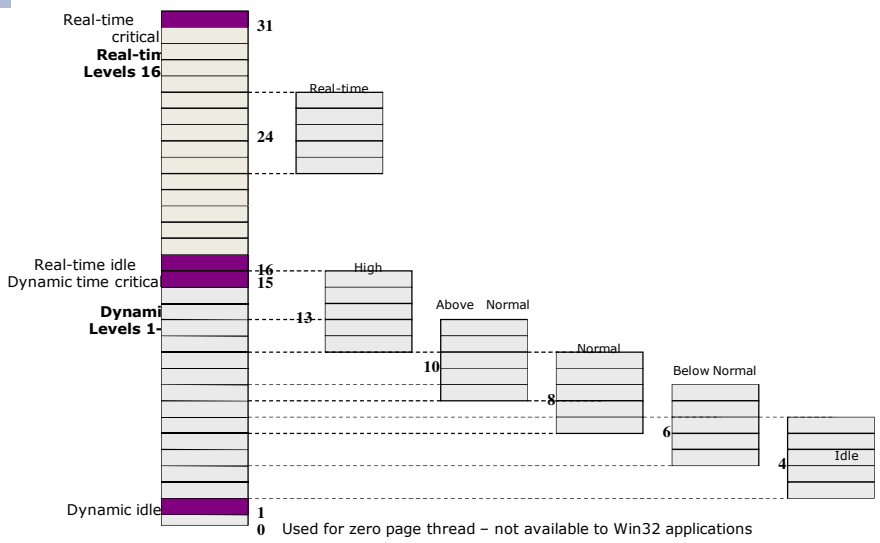

Valores de Aumento da Prioridade

Device	Boost
Disck, CD-ROM, parallel, video	**1**
Network, mailslot, named pipe, serial	**2**
Keyboard, mouse	**6**
Sound	**8**